



数据挖掘与商务分析

第2讲 数据预处理

主讲教师：肖升生



课程导入

- 从自身的研究经历说起……



VS.





讲授提纲

- 01 数据预处理概述**
- 02 数据清理**
- 03 数据抽样**
- 04 数据规约**
- 05 数据变换**
- 06 数据预处理案例**



讲授提纲

01 数据预处理概述

02 数据清理

03 数据抽样

04 数据规约

05 数据变换

06 数据预处理案例



数据集形式


列：属性、特征、变量

Tid	Refund	Marital Status	Taxable Income	Cheat
1	Yes	Single	125K	No
2	No	Married	100K	No
3	No	Single	70K	No
4	Yes	Married	120K	No
5	No	Divorced	95K	Yes
6	No	Married	60K	No
7	Yes	Divorced	220K	No
8	No	Single	85K	Yes
9	No	Married	75K	No
10	No	Single	90K	Yes



属性的测度和取值

- 属性和属性取值之间是有区别的
- 属性的取值与属性测度





属性类型

■ 标称属性 (Nominal)

- 如身份证号码, 邮编, 国籍

■ 序数属性 (Ordinal)

- 如成绩等级{A,B,C}、收入水平{高、中、低}, 教师职称{教授、副教授、助理教授}

■ 区间属性 (Interval)

- 如日期、摄氏温度

■ 比率属性 (Ratio)

- 如长度、价格、数目



属性类型判定

■ 属性类型的判定取决于能否进行下列运算：

- 取等 (Distinctness) : $= \neq$
- 排序 (Order) : $< >$
- 加减 (Addition) : $+ -$
- 乘除 (Multiplication) : $\times \div$

- 标称属性: 取等
- 序数属性: 取等、排序
- 区间属性: 取等、排序、加法
- 比率属性: 取等、排序、加法、乘法



“脏”数据


现实世界的数据是“脏”的

- 不完整
- 含噪声
- 不一致

数据为什么会变“脏”？

- 收集缺乏合适值的数据、人为/硬件/软件问题……
- 数据收集工具、数据输入时人为错误、传输中产生的错误……
- 时空不一致的数据源、冗余数据的修改不完全……

Kaggle调查：机器学习人员在工作中的最大障碍?






数据质量的多维度量

- 准确性 (Accuracy) : 数据的记录状态能够准确表示物理世界实际状况的程度;
- 完整性 (Integrity) : 描述特征、特征属性和特征关系的完善程度;
- 一致性 (Consistency) : 数据集记录、格式、内容等方面的一致程度;
- 时效性 (Timeliness) : 描述数据的更新频次对数据质量的影响;
- 可信性 (Believability) : 描述数据的正确性的可信程度;
- 可解释性 (Interpretability) : 描述数据被理解的程度;
-



数据预处理的作用

- 原因：现实世界的大数据质量不高，存在不完整、不一致、不准确等问题；
- 作用：数据预处理可以改进数据质量，有助于提高数据挖掘的准确率和效率。





数据预处理的主要步骤

■ 数据清理 (Data Cleaning)

- 把“脏”数据变成“干净的”，提升数据质量；
- 如处理缺失值，光滑噪声数据，处理离群点，解决不一致性等；

■ 数据抽样 (Data Sampling)

- 抽取有代表性的数据记录，进行挖掘分析；

行的选取

■ 数据规约 (Data Reduction)

- 寻找针对目标任务的有用特征，以缩减数据规模，并达到基本一致的挖掘效果；
- 维规约、属性子集选择；

列的精简

■ 数据变换 (Data Transformation)

- 通过特定函数将原属性取值映射到新的函数空间。
- 规范化、离散化、简单函数变换

值的映射



讲授提纲

01 数据预处理概述

02 数据清理

03 数据抽样

04 数据规约

05 数据变换

06 数据预处理案例



数据清理

■ 目标：把“脏”数据变成“干净的”，提升数据质量；

■ 数据清理的主要任务

- 处理缺失值；
- 光滑噪声数据；
- 识别或删除离群点；
- 解决数据中的不一致性；
- 删除重复数据；





缺失值的类型

■ 完全随机缺失 (Missing completely at random)

- 某字段是否缺失与自身和其他观测变量无关，是完全随机的；
- 比如机器完全随机采样造成；

■ 随机缺失 (Missing at random)

- 某字段缺失的概率不是完全随机的，可以由其他观测变量解释；
- 比如问卷调查中，收入数据的缺失可能与受访者性别有关；

■ 不随机缺失 (Missing not at random)

- 字段缺失的概率与该字段本身的取值有关；
- 比如收入数据的缺失可能与受访者本身收入高低有关；





处理缺失值

■ 删除整条观测数据

- 当类别数据缺失时通常这么做；
- 适合数据集中缺失值较少的情况；

■ 人工填补缺失值：工作量大，可行性低

■ 自动填补缺失值

- 使用一个全局变量：比如unknown或0
- 使用属性的中心度量：平均值、中位数
- 使用最可能的值填充：基于贝叶斯模型或决策树自动推断





噪声

- 噪声是测量误差的随机部分，如值被扭曲或加入了偏误；



(a) 时间序列

(b) 加入噪声的时间序列

思考：如果噪声偏误进一步增大呢？



光滑噪声数据

■ 分箱

- 首先排序数据，并将他们分到等深的箱中；
- 然后按箱的平均值、中值或边界值平滑数据。

■ 回归

- 通过使数据拟合一个回归函数来平滑数据；
- 试图发现相关变量之间的变化模式；

■ 聚类

- 通过聚类来检测并删除离群点；

通过分箱平滑数据

划分为（等深的）箱：

箱1：4, 8, 15

箱2：21, 21, 24

箱3：25, 28, 34

用箱平均值平滑：

箱1：9, 9, 9

箱2：22, 22, 22

箱3：29, 29, 29

用箱边界平滑：

箱1：4, 4, 15

箱2：21, 21, 24

箱3：25, 25, 34




离群点

■ 离群点 (outliers) : 不同于数据集中大部分对象取值的特殊对象，也称为异常对象或异常值；

■ 区分噪声和离群点

- 噪声：不正确的、偏误数据；
- 离群点：取值上“异于常人”；
- 关系：离群点可能是噪声，也可能是真实、正确的数据；



■ 离群点检测的应用

- 信用风险监测、网络入侵检测等



离群点检测方法

■ 基于模型的技术



- 建立数据表征模型，模型不能完美拟合的对象为“离群点”；

■ 基于邻近度的技术

- 定义对象之间的临近性度量，远离大部分其他对象的则是“离群点”；

■ 基于密度的技术

- 通过数据估计对象分布的密度，分布密度明显低于其他部分的称之为“离群点”。



详见《数据挖掘导论》第10章异常检测



小结

■ 数据清理的目标

- 把“脏”数据变成“干净的”，提升数据质量；

■ 数据清理的主要任务

- 处理缺失值：删除、统一插补、自动推断；
- 光滑噪声数据：分箱、回归、聚类；
- 识别或删除离群点：基于模型、邻近度、密度的技术
- 解决数据中的不一致性；
- 删重复数据；





讲授提纲

01 数据预处理概述

02 数据清理

03 数据抽样

04 数据规约

05 数据变换

06 数据预处理案例



数据抽样导入

一天爸爸叫儿子去买一盒火柴，临出门前爸爸嘱咐儿子要买能划燃的火柴。儿子拿着钱出门了。过了一会儿，儿子才回到家。

“火柴能划燃吗？”爸爸问。

“都能划燃。”儿子递过一盒划过的火柴，兴奋地说：“我每根都试过了。”






抽样的思想

■ 用样本估计总体

- 即通常不直接去研究总体，而是通过从总体中抽取一部分样本，根据样本的情况去估计总体的相应情况。

■ 关键原则：选取有**代表性的子集**；





数据抽样的作用


■ 作用

- 允许用数据的较小随机样本子集，表示较大的数据集；
- 压缩数据量，允许在计算能力有限的情况下使用复杂度高的挖掘算法；
- 解决样本不均衡的问题，比如异常检测中对与少数类采用“过采样”；






抽样方法







简单随机抽样

- 简单随机抽样：从总体中抽取一定的样本，每个对象被抽取的概率相等；
- 两种变形：无放回/有放回



SRSWOR
(无放回
简单随机抽样)

SRSWR
(有放回
简单随机抽样)




1.选中的样本立即
从总体删除；
2.每轮样本被选中
的概率是变化的；

1.选中的样本不从总
体删除，同一样本可
能被采样多次；
2.每轮样本被选中的
概率是一致的；

系统抽样

- 将总体个体按一定顺序**随机**编号，按编号**固定间隔**取样。
 - 编号顺序一定要随机打乱；
 - 间隔大小根据样本容量/总体大小而定；



- 适用性
 - 当总体规模较大或样本容量较多时，采用简单随机采样效率低，更适合**系统（等距）采样**。



整体抽样


- 当总体中归并成若干个互不相交、互不重复的群，然后以群为单位抽样，随机抽取若干个群，组成抽样的总体。
 - 整体抽样要求各群有较好的代表性，即群内各单位的差异要大，群间差异要小；
 - 比如移动模式挖掘时，以“地区”为单位抽样，将北京作为中国大城市的代表；





分层抽样

- 当总体由几种特定类型（“层”）的对象组成时，对每个“层”分别进行随机抽样；



适用性

- 当每种类型的对象数量差别很大时，简单随机抽样不能充分代表不太频繁出现的对象类型，适合采用分层抽样；

采样规模

- 尽管每组大小不同，但从每组抽取的样本个数相同；
- 根据每组占总体的比例确定分层采样规模；




不平衡抽样

■ 适用性

- 针对数据挖掘中的不平衡数据集（如分类类别不平衡）；

■ 过采样/欠采样

欠采样多数类别



原始数据

样本

过采样少数类别



原始数据

样本




小结

■ 数据抽样的思想和关键原则

- 以样本代表总体，代表性；

■ 数据抽样的好处

■ 数据抽样方法





讲授提纲

- 01** 数据预处理概述
- 02** 数据清理
- 03** 数据抽样
- 04** 数据规约
- 05** 数据变换
- 06** 数据预处理案例



数据规约

- 目的：降低数据维度的同时，保证基本一致的挖掘效果；
- 维度诅咒（Curse of dimensionality）：当维度增加时，数据在它对应的空间中变得愈加稀疏。
 - 数据点间的距离和密度对于聚类至关重要；
 - 子空间的可能组合会呈指数级增长，影响诸如关联分析等任务。
- 两种典型方案
 - 维规约（Dimension Reduction）：通过创建新属性，将旧属性合并表示来降低数据集的维度；
 - 属性子集选择（feature subset selection）：不创建新属性，而是选择原属性的子集；



维规约


- 维规约：常采用线性代数技术，将高维空间（原属性空间）投影到低维空间（新属性空间）；
- 维规约的好处
 - 避免维度诅咒；
 - 帮助去除不相关特征和减弱噪声；
 - 减少数据挖掘的时间和空间需求；
 - 使得数据可视化更轻松；
- 典型技术：主成分分析（Principle Component Analysis, PCA）



主成分分析

■ 主成分分析：通过正交变换，将多个可能存在相关性的变量（原属性）转换为少量线性不相关的变量（新属性），以达到降维度的目的。

- 转换后的新属性叫主成分，是原属性的线性组合；
- 新属性两两之间彼此正交；
- 目标：尽可能捕捉原数据的最大方差；
- 仅适用于数值属性。




找出一个能保留
原属性最大方差
的投影方向




主成分分析：以房价为例

	房价(百万元)	面积(百平米)
a	5.4	4.4
b	-2.6	-1.6
c	-3.6	-2.6
d	2.4	1.9
e	-1.6	-2.1

	主元1	主元2
a	-6.94	0.084
b	3.02	0.364
c	4.42	0.204
d	-3.05	-0.006
e	2.55	-0.646



知乎 @马同字





属性（特征）子集选择

■ 降低数据维度的又一种方法，用于去除以下属性：

- 噪音属性：属性取值基本一致，**方差很小**；
- 冗余属性：与其他属性存在**高度相关**，没有新的信息；
- 无关属性：与学习任务**不相关**，如学生ID对于GPA预测。



特征选择方法

- 过滤法 (Filter) : 用一系列统计指标筛选出部分特征, 特征选择与机器学习算法无关;
- 包裹法 (Wrapper) : 选出多个可能的特征子集, 基于机器学习算法指标评估特征子集的质量 (特征子集包裹机器学习) ;
- 嵌入法 (Embedding) : 特征选择与机器学习模型融为一体, 基于统一的优化目标同时学习模型和筛选特征;



小结

- 数据规约：降低数据维度的同时，保证基本一致的挖掘效果；
- 维规约 (Dimension Reduction)
 - 通过创建新属性，将旧属性合并表示来降低数据集的维度；
 - 主成分分析：基于正交变换寻找捕捉原数据最大方差的主成分；
- 属性子集选择 (feature subset selection)：
 - 不创建新属性，而是选择原属性的子集；
 - 去除噪音、冗余、无关属性；
 - 过滤法、包裹法、嵌入法。



讲授提纲

01 数据预处理概述

02 数据清理

03 数据抽样

04 数据规约


05 数据变换

06 数据预处理案例



数据变换

- 通过特定函数将原属性取值映射到新的函数空间。



- 典型方式

- 离散化
- 规范化（或标准化）
- 简单函数变换



离散化

■ 将连续数值属性映射到离散区间；

■ 离散化的原因

- 一些算法只接受离散化的输入；
- 降低数据规模。

■ 离散化技术

- 等宽离散化 (Equal-width discretization)
- 等深离散化 (Equal-depth discretization)
- 基于聚类的离散化 (Clustering-based discretization)




等宽离散化

- 将原属性取值范围 (\min, \max) 分成 N 个宽度相等的区间，每个区间的宽度 L 记为：

$$L = \frac{\max - \min}{N}$$

■ 特点

- 最直接有效的离散化方式，但不适用于有偏的数据；
- 对于 N 和异常点敏感；



等宽离散化




等深离散化

- 将原属性取值范围分成 N 个区间，使得每个区间包含个数相等的数据点；
- 又叫等频 (Equal-frequency) 离散化。

■ 特点


- 具备较好的数据伸缩特性，更能应对有偏的数据；
- 对异常点不那么敏感；









基于聚类的离散化

- 采用聚类技术将原属性取值范围划分为几个聚簇（区间）；
- 特点
 - 能考虑数据点的分布和邻近性，同一区间数据点尽可能临近，不同区间数据点尽可能分离；
 - 能产生高质量、符合人类感知的离散化结果。
- 典型技术：基于K-Means的离散化





离散化方法图示






规范化

■ 将不同属性的取值放缩到同一个较小的、指定的区间；

■ 规范化的原因

- 不同属性使用不同的量纲；
- 取值范围大的属性占主导作用、
取值范围小的属性变得不重要。



■ 规范化技术


- 最小-最大标准化（min-max normalization）
- 正态规范化（z-score normalization）



最小-最大标准化

- 假定某属性原来的取值范围是 (min, max) , 变换后取值范围是 (min', max') , 则原属性取值 v 变换为:



$$v' = \frac{v - min}{max - min} (max' - min') + min'$$





最小-最大标准化



■ 思考：考虑异常点的情况下，最小-最大标准化表现如何？





正态规范化

- 基于属性A的均值 \bar{A} 和标准差 σ_A 进行规范化: $v' = \frac{v - \bar{A}}{\sigma_A}$





规范化方法对比


最小-最大规范化	正态规范化
可限定取值范围($\min^{'}, \max^{'}$)	无法限定取值范围: $(-\infty, +\infty)$
均值、标准差不定	变换为标准正态分布，均值为0，标准差为1
对异常点敏感	能较好的应对异常点
作用：映射到特定范围，如图像处理中RGB颜色(0, 255)	作用：无量纲化，适用于距离计算和利用梯度下降寻优的模型 (如逻辑回归、SVM)



简单函数变换

■ 利用简单的数学函数，实施变量变换；

- 如 $\log x, \sqrt{x}, 1/x$, 常将不具有正态分布的数据变换得具有正态分布；



- 注意：谨慎使用变量变换，因为改变了数据特性；



小结

- 数据变换：通过特定函数将原属性映射到新的函数空间。



- 离散化：等宽、等深、聚类离散化
- 规范化：最小-最大、正态规范化
- 简单函数变换：使用 $\log x$ 、 \sqrt{x} 等，改变数据分布特性



本章梳理总结

